Eksploracja zastosowań sztucznej inteligencji generatywnej i LLM

Streszczenie

Ostatni postęp w dziedzinie sztucznej inteligencji (AI) – generatywnej sztucznej inteligencji (GenAI) – to niezwykle potężna forma wspierająca zinformatyzowaną strukturę organizacyjną społeczeństwa. Niniejszy rozdział zgłębia najnowsze metodologie i różnorodne zastosowania dużych modeli językowych w badaniach naukowych i technicznych. W rozdziale tym analizowane jest przede wszystkim ich zasadnicze znaczenie dla rozwoju różnych technik badawczych w dziedzinach naukowych. Model ten znacząco przyczynił się do powstania licznych narzędzi poprzez zrozumienie i dostarczenie kodu źródłowego instrukcji opartych na języku naturalnym. Rozdział koncentruje się na integracji danych na poziomie, którą określa się mianem adaptacyjnej, wykorzystując techniki kwantowe, podkreślając ich zalety w modelowaniu dziedziny naukowej z kompleksowym tworzeniem kontekstu. Techniki niezbędne do zachowania poufności, transferu wiedzy z wykorzystaniem sieci neuronowych oraz interakcji zespołowej z pracami badawczymi są szczegółowo analizowane, zwracając szczególną uwagę na dostarczane dane oraz na solidność wymaganą w zastosowaniach AI. W rozdziale przedstawiono udane zastosowania generatywnych sieci neuronowych w postępie badań naukowych. GenAI okazuje się cennym źródłem wiedzy zarówno dla badaczy, jak i specjalistów.

Słowa kluczowe: sztuczna inteligencja, adaptacyjne modelowanie naukowe, blockchain, generatywna sztuczna inteligencja, duże modele językowe, metodologie inspirowane teorią kwantową.

Przegląd generatywnej sztucznej inteligencji (AI)

Nowe materiały, takie jak obrazy, teksty, muzyka, a nawet kompletne sytuacje, które często różnią się od tych tworzonych przez ludzi, mogą być tworzone przez maszyny dzięki generatywnej sztucznej inteligencji (GenAI), podzbiorowi sztucznej inteligencji (AI). W porównaniu z innymi formami tradycyjnych systemów, które koncentrują się głównie na regułach i wzorcach danych, modele GenAI pozyskują lub uzyskują wystarczającą ilość danych w oparciu o unikalne architektury głębokiego poziomu, takie jak generatywne sieci adwersarskie (GAN) lub autokodery wariacyjne (VAE), dostarczając unikalne wyniki z wykorzystaniem zestawów danych dywidendowych. Analizują one poprzez imitacje fundamentalnych koncepcji, gdzie dane koncentrują się na realistycznych, wartościowych punktach danych. Adaptacyjne rozwiązania naukowe zrewolucjonizowały zależność od technologii blockchain w zakresie prawidłowej replikacji i zaufania do systemów wspomagania decyzji w czasie rzeczywistym, algorytmów opartych na interakcji uczenia maszynowego w celu efektywnej predykcji z szybkimi obliczeniami oraz przetwarzania informacji w celu naukowej wizualizacji z wykorzystaniem metodologii inspirowanych kwantami. GenAI jest wykorzystywane w różnych dziedzinach związanych z tworzeniem treści, na przykład w sztuce, gdzie skutecznie prezentuje swój potencjał w tworzeniu efektywnych materiałów dzięki wygenerowanemu rozkładowi stronniczości danych treningowych. Praktyczne implikacje dla przyszłych prac nad tymi postępami przedstawiono na przykładach studiów przypadku. Wraz z rozwojem GenAI, trudności te muszą zostać rozwiązane, a jednocześnie potencjał transformacyjny GenAI zostanie odpowiednio wykorzystany. Rysunek przedstawia wykorzystanie GenAI w sektorze opieki zdrowotnej.

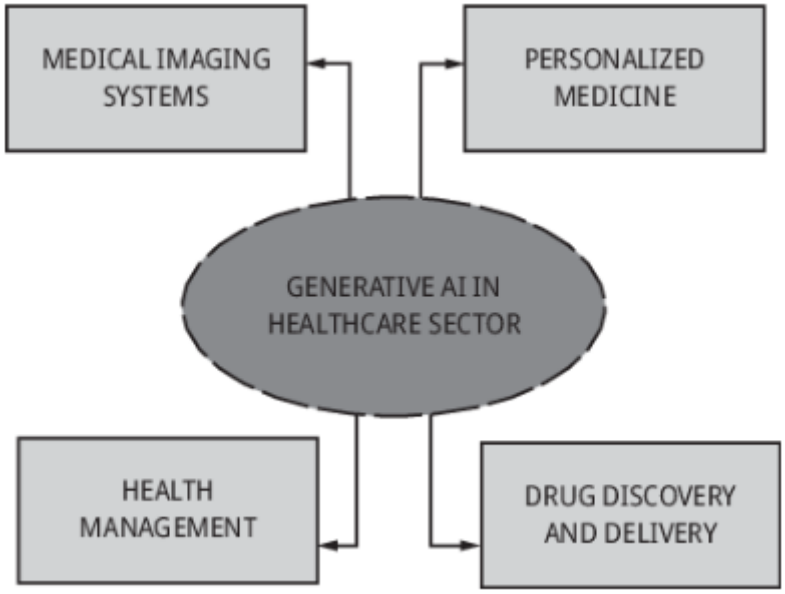

Generatywny model dużego języka (LLM), znany również jako generatywny model dużego języka, to przełomowy postęp w przetwarzaniu języka naturalnego, czyli NLP, w dziedzinie sztucznej inteligencji. Główny nacisk w tym modelu położony jest na architekturę podstawową, taką jak generatywna architektura OpenAI, która działa jak wyszkolony konwerter generujący spójny i kontekstowy tekst, który służy jako poprawny monit lub warunek wejściowy. Nie przypomina on tradycyjnych technik, które opierają się na szablonach lub regułach; zamiast tego wykorzystuje techniki głębokiego uczenia, które pomagają w generowaniu i ocenie języków humanizowanych. Modele te są trenowane na dużych zbiorach danych zebranych z różnych źródeł, co pozwala im rozumieć złożone wzorce mowy, skomplikowane struktury morfologiczne, a także powiązania kontekstowe. Uczą się one również poprzez nienadzorowane uczenie się wzorców językowych, co zapewnia odpowiedni i znaczący kontekst dla fragmentów tekstu. Model uczenia się języka znajduje zastosowanie głównie w produkcji tekstów, systemach dyskusyjnych, rozumieniu języka naturalnego, a także w tworzeniu materiałów. Wymienione modele realizują syntezę, opowiadanie historii, odpowiadanie na zapytania, tworzenie kodu i szeroki zakres innych zadań. Choć posiadają one różnorodne możliwości, wiążą się z nimi różne problemy etyczne, takie jak interpretowalność modelu, ograniczenia treści, dezinformacja, stronniczość i niewłaściwe użycie. Różni badacze pracują nad rozwiązaniem tych problemów, stosując różne metody, takie jak unikanie wartości stronniczych. W związku z tym, LLM-y wykazały liniowy wzrost sztucznej inteligencji, która jest osadzona w konwersacyjnym sposobie przetwarzania danych, stanowiąc potężne narzędzia do interpretacji i generowania humanistycznego tekstu. Wraz z ciągłym doskonaleniem w tym obszarze, pojawiają się możliwości transformacji, zależne od interakcji między tworzeniem treści a wymianą informacji na forum cyfrowym.

Podstawy metauczenia się w adaptacyjnym modelowaniu naukowym

Ta zaawansowana forma techniki uczenia maszynowego i sztucznej inteligencji opiera się wyłącznie na modelu, który umożliwia mu uczenie się i adaptację do konkretnego zadania lub zjawiska. Metauczenie się to skuteczna metoda, która pomaga zwiększyć jej efektywność, generując równania modelowania matematycznego poprzez analizę koncepcji za pomocą adaptacyjnej, empirycznej formy modelowania. Metauczenie koncentruje się wyłącznie na nauczaniu modeli, które rozpoznają wzorce w procesie uczenia się, co pomaga im w przenoszeniu treści, dostosowując się do nowych warunków, przy minimalnych parametrach wejściowych. W dziedzinie symulacji opartych na danych empirycznych ta forma uczenia się polega na integracji nowo opracowanych struktur z algorytmami, które absorbują

wiedzę z różnych dziedzin, w celu zwiększenia produktywności związanej z nowymi warunkami badawczymi .Rysunek 2 przedstawia strategię ścieżki uczenia się w modelowaniu GenAI.

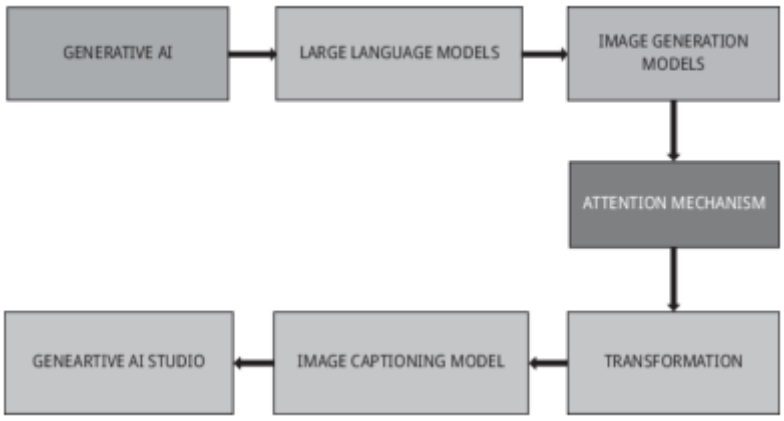

Kluczowe zasady metauczenia się w adaptacyjnym modelowaniu naukowym

Uczenie się uczenia się

Algorytmy metauczenia się pomagają w zdobywaniu metawiedzy w oparciu o proces uczenia się, co pozwala im na efektywne przyswajanie wiedzy przy ograniczonym zbiorze informacji i generalizowanie nowych wartości kontekstowych.

Ekstrakcja i reprezentacja cech

Algorytmy metauczenia się reprezentują działania lub informacje na temat wzorców szybkiej adaptacji, które wydobywają sensowną reprezentację. To wyodrębnia różne informacje z surowych danych i pomaga w identyfikacji paralelizmu między różnymi dziedzinami nauki.

Transfer uczenia się

Metauczenie się ulepszone dzięki transferowi uczenia się pomaga w przekazywaniu informacji z jednego stanu aktywności do drugiego, co przyspiesza proces adaptacji, oferując nowe, intelektualne przewagi.

Model Agnostic Meta Learning (MAML)

MAML to rozwijający się framework metauczenia się, który jest w szczególności przeznaczony do uczenia się wszystkich wartości parametrycznych opartych na modelu, umożliwiając szybką adaptację do nowego zadania. Celem jest nauczanie za pomocą ilustracji poprzez zrozumienie kluczowych parametrów, które następnie można dostosować do różnych nowych zadań. →Tabela 8.1 przedstawia różne warstwy GenAI w interfejsach architektonicznych .

Sprzęt: Zoptymalizowane układy scalone, które pomagają w szkoleniu i uruchamianiu LLM

Platformy chmurowe: Platformy chmurowe ze skalowalnym sprzętem

Warstwy modelowania: Wstępnie wytrenowane z wykorzystaniem większej ilości danych

Narzędzia z frameworkiem: Warstwa znajdująca się pomiędzy warstwą fundamentową a GenAI

Aplikacja: Produkty/aplikacje generatywnej AI

Usługi: Usługi są w całości oparte na generatywnych aplikacjach AI

Bayesowskie metauczenie

Bayesowskie systemy metauczenia posiadają różne oszacowania dotyczące niepewności związanej z metatranslacjami, co pomaga komputerom w uzyskiwaniu i podejmowaniu decyzji, oferując lepszą adaptację do różnych problemów modelowania [→10]. Te integracje pomagają w adaptacyjnych, współczesnych procedurach, które pomagają badaczom w opracowaniu symulacji, która jest precyzyjna i dostosowana do wymagań systemowych w procesie badań naukowych. Polega to wyłącznie na zmianie w prowadzeniu modeli oraz analizowaniu i rozwiązywaniu złożonych przypadków w bardziej efektywny i szybszy sposób.

Automatyczne generowanie hipotez z wykorzystaniem modeli generatywnych

Modele tworzone z wykorzystaniem automatycznego tworzenia hipotez zapewniają regeneracyjne, niezawodne przecięcie na inteligentnych maszynach z nowatorskimi osiągnięciami naukowymi. Systemy te są zaprojektowane tak, aby przecinały się na inteligentnych maszynach z postępem naukowym [→11]. Wszystkie te modele generatywne, zbudowane w oparciu o rozwiązania głębokiego uczenia, takie jak VAE i GAN, mają zdolność generowania nowych i dokładnych hipotez przy użyciu stronniczych danych wejściowych. Procedura zazwyczaj składa się z następujących kroków, pokazanych na rysunku 3.

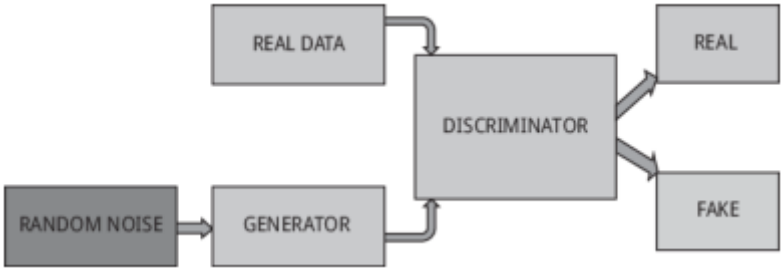

Reprezentacja danych

Dane wejściowe, głównie dane z obserwacji eksperymentalnych lub badań literatury naukowej, są przetwarzane w formacie umożliwiającym ich prezentację i użyteczność w celu tworzenia modeli generatywnych. Obejmuje to zarówno systematyczne, jak i numeryczne kodowanie wzorców informacyjnych.

Trening modelu

Modele generatywne są trenowane w zakresie obsługi dużych wolumenów danych, co pomaga w identyfikacji określonych wzorców strukturalnych. Podczas takiego treningu algorytm pomaga w uczeniu się lub generowaniu dodatkowych punktów danych, które są podobne do uzyskanych danych wejściowych .

Generowanie hipotez

Nowy wzorzec hipotezy jest tworzony poprzez wybór modeli generatywnych i trenowany z wykorzystaniem poprzednich danych wejściowych do generowania wzorców rozkładu. Te wzorce spekulatywne wymagają większej liczby kształtów wejściowych, badań, a także rodzaju gromadzonych informacji. Rysunek 4 przedstawia różne aplikacje współpracujące z GenAI.

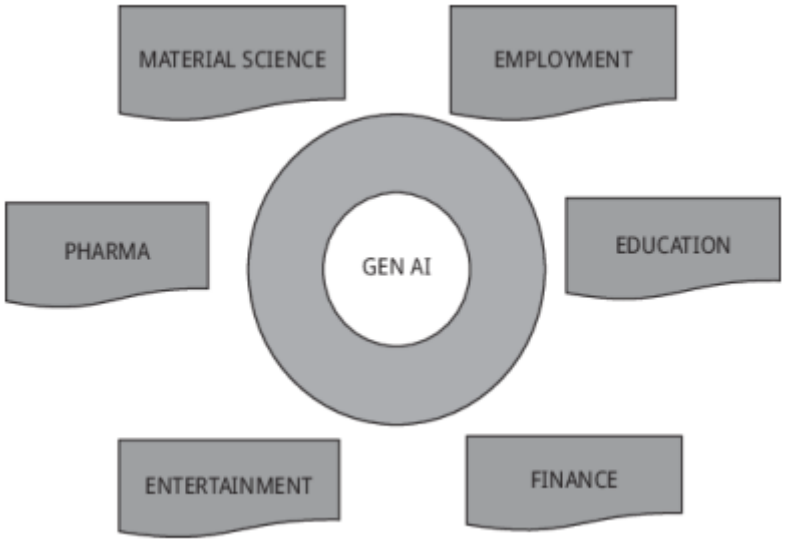

Ocena i walidacja

Wygenerowane hipotezy są następnie oceniane i weryfikowane za pomocą różnych norm kryteriów, które stosują regułę zgodności opartej na wiedzy z wiedzą, efektem i warunkami testowania [→13]. Wymaga to bardziej eksperymentalnych wzorców analizy w celu określenia przydatności i walidacji tworzonej hipotezy.

Iteracyjne udoskonalanie

Automatyczny system tworzenia hipotez z wykorzystaniem generatywnych modeli sztucznej inteligencji oferuje ogromny potencjał w warunkach odkryć naukowych, uzupełniając ludzką wyobraźnię o większe możliwości obliczeniowe zaangażowanej w nią sztucznej inteligencji [→14]. Poprzez staranną analizę znacznie szerszego zakresu ulepszonych hipotez, modele generatywne dostarczają nowych wzorców wglądu, których metoda naukowa by nie zauważyła. Kluczowe jest zrozumienie ograniczeń generowanych wzorców algorytmicznych, a interpretacja hipotezy powinna być ostrożna, bez uwzględniania takich aspektów, jak z góry przyjęte założenia modelu, błędy statystyczne i ekspertyza w określonych dziedzinach. Dzięki postępowi badań naukowych automatyczne stawianie hipotez stało się potężnym narzędziem zwiększającym zrozumienie i rozwiązywanie skomplikowanych problemów w scenariuszach z życia wziętych.

Koncepcje obliczeń kwantowych w modelach generatywnych

Aby obsługiwać skomplikowane wzorce dystrybucji danych, a także przetwarzać oczywiste problemy obliczeniowe, w przeważającej mierze wykorzystuje się zasady obliczeń kwantowych wraz z modelami generatywnymi. Rysunek 5 przedstawia elementy składowe GenAI na różnych warstwach kaskadowych. Kilka kluczowych koncepcji wraz ze zdefiniowanymi metodami zapewnienia interfejsu dla komputerów kwantowych obejmuje:

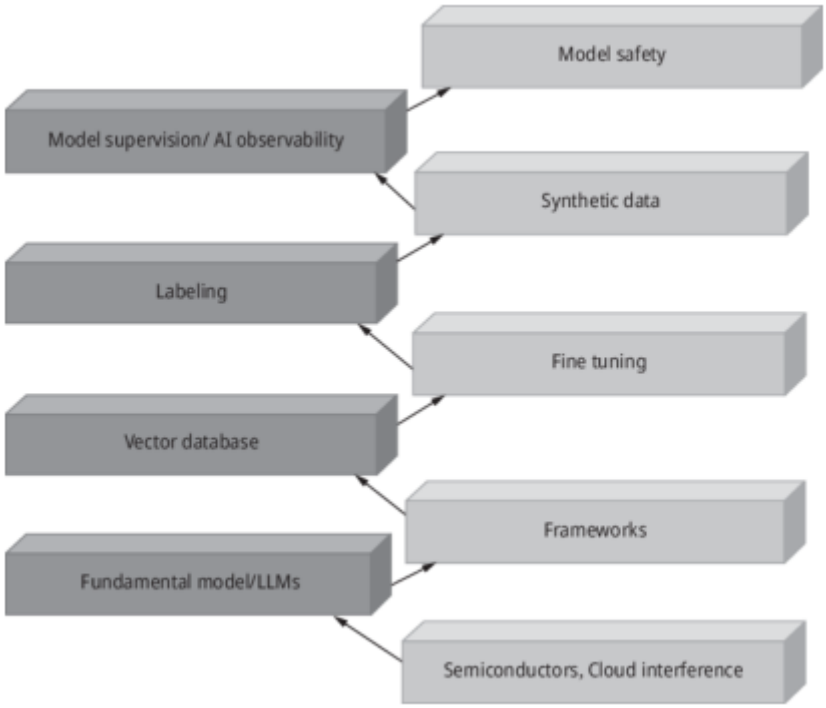

Modele generatywne kwantowe

Koncepcje obliczeń kwantowych są wykorzystywane w modelach generatywnych kwantowych do tworzenia rozkładów danych . Dane są kodowane i przetwarzane za pomocą obwodów kwantowych, które wykorzystują zjawiska kwantowe, takie jak superpozycja i splątanie, aby skutecznie tworzyć selekcje z wielowymiarowych rozkładów prawdopodobieństwa.

Modele wariacyjnych obwodów kwantowych (VQC)

Zarówno elementy klasyczne, jak i kwantowe są wykorzystywane w modelach wariacyjnych obwodów kwantowych (VQC) do reprezentowania i rozumienia skomplikowanych rozkładów danych. Wykorzystując koncepcję generowania próbek z rozproszonego systemu modelowego, obwody obliczeń kwantowych w takich modelach VQC wykorzystują parametry trenowane i modyfikowane przez metody optymalizacji klasycznych reprezentacji kwantowych.

Kwantowe maszyny Boltzmanna

Konwencjonalna forma silnika Boltzmanna, która jest przedstawiana jako wersja modelu kwantowego, jest wykorzystywana przez kwantowe maszyny Boltzmanna z modelowaniem matematycznym. Posiada ona grupę kodów, które działają w nanosekundach, wykorzystując zasadę mechaniczną, co pomaga w wykrywaniu skorelowanych próbek danych z rozproszonych sekwencji.

Kwantowe autoenkodery wariacyjne (QVAE)

Kwantowe wersje klasycznych autoenkoderów wariacyjnych wykorzystują koncepcję modelowania generatywnego, reprezentowaną przez QVAE [→20]. Pomagają one w efektywnym kodowaniu i dekodowaniu modeli reprezentacji informacji z optymalizowaną przestrzenią utajoną w algorytmach wariacyjnych, znając rozkład parametrów.

Kwantowe generatywne sieci przeciwstawne Boltzmanna (QB-GAN)

Obliczenia kwantowe oparte na sieciach GAN z QB-GAN działają głównie jako generator kwantowy i dyskryminator, generując próbki o wartościach rzeczywistych z rozproszeniem danych. Zapewnia to wysoką wierność rozproszonych zbiorów danych .

Wyżarzacze kwantowe do próbkowania

Wyżarzacz kwantowy, będący modelem generatywnym, pomaga w analizie złożonych rozkładów prawdopodobieństwa. Procesy tunelowania kwantowego są wykorzystywane przez te urządzenia do efektywnego eksplorowania przestrzeni rozwiązań i generowania próbek o zamierzonym rozkładzie. Te pomysły to jedynie przedsmak rozwijającego się obszaru obliczeń kwantowych w modelowaniu predykcyjnym. Ze względu na obecne ograniczenia sprzętowe i problemy z uczeniem maszynowym, praktyczne zastosowanie kwantowych modeli generatywnych jest obecnie na wczesnym etapie, ale oczekuje się, że trwające badania i udoskonalenia zarówno komputerów kwantowych, jak i generatywnego generowania modeli otworzą w przyszłości nowe możliwości generowania i analizowania złożonych lokalizacji danych.

Współpraca w czasie rzeczywistym z modelami generatywnymi

Współpraca w czasie rzeczywistym z sieciami neuronowymi AI otwiera nowe możliwości innowacyjnych i dochodowych przedsięwzięć w różnych dziedzinach, w tym w sztuce, projektowaniu, badaniach naukowych i inżynierii. W tym kontekście współpraca w czasie rzeczywistym z modelami generatywnymi stanowi kuszącą możliwość wykorzystania połączonych kreatywnych umysłów i wiedzy osób z różnych dziedzin. Dzięki wdrożeniu generatorów na współdzielonych platformach i narzędziach, użytkownicy mogą współpracować i wchodzić w interakcje w czasie rzeczywistym, łącząc swoje wysiłki z systemami AI, aby generować, ulepszać i tworzyć treści w różnych trybach, takich jak zamiana tekstu na muzykę. To środowisko partnerskie ułatwia nawiązywanie kontaktów i wymianę pomysłów między użytkownikami, umożliwiając im współpracę z systemami AI i wdrażanie nowych podejść. Jedną z najważniejszych ról ciągłej współpracy z modelami generatywnymi jest tworzenie kreatywnych treści. Platformy współpracy wyposażone w modele generatywne pomagają ludziom wspólnie rozwijać kreatywne produkty, innowacyjne projekty produktów i innowacyjne rozwiązania. Przykładem tego jest to, że modele generatywne wspomagane przez AI pozwalają użytkownikom współpracować z użytkownikami oprogramowania do projektowania graficznego w eksploracji różnych koncepcji kreatywnych, a także w natychmiastowym iterowaniu kompozycji wizualnych. Z kolei w programach do komponowania muzyki muzycy mogą pracować z melodiami i harmoniami generowanymi przez AI, komponując wspólnie muzykę, łącząc w ten sposób treści generowane przez AI z ludzką kreatywnością, aby tworzyć interesujące i wciągające kompozycje. Ponadto współpraca w czasie rzeczywistym z modelami generatywnymi sprzyja współdziałaniu i dzieleniu się wiedzą między ekspertami z różnych dziedzin. Współpraca z modelami generatywnymi na platformach współpracy umożliwiła osobom z różnym doświadczeniem i doświadczeniem równoczesną pracę nad skomplikowanymi problemami, wymianę pomysłów i natychmiastowe wspólne opracowywanie rozwiązań. Na przykład, w przypadku projektów badawczych, naukowcy mogą współpracować z modelami generatywnymi opartymi na sztucznej inteligencji, analizując skomplikowane zbiory danych, formułując hipotezy i przeprowadzając wirtualne eksperymenty. Ta interdyscyplinarna relacja umożliwia wymianę myśli, sprzyja innowacyjności i rozwija kreatywne i eksploracyjne środowisko dla projektów współpracy.

Interaktywne interfejsy

Interaktywne interfejsy w GenAI zapewniają przyjazny i atrakcyjny interfejs użytkownika, umożliwiając użytkownikom wpływanie na modele generatywne i kontrolowanie ich w czasie rzeczywistym. Interfejsy te działają jako kanał komunikacji między ludźmi a sztuczną inteligencją, ułatwiając dwukierunkowy przepływ zapytań, aktualizacji parametrów, wizualizację wyników i informacji

zwrotnych od użytkowników. Interfejs GenAI pozwala użytkownikom odkrywać, testować i współtworzyć systemy AI, dzięki czemu mogą korzystać z nich w sposób interaktywny. Platformy współpracy mogą oferować przyjazne dla użytkownika interfejsy, które umożliwiają wielu użytkownikom jednoczesną interakcję z modelami generatywnymi AI. Interfejsy te mogą zawierać narzędzia wizualizacji w czasie rzeczywistym oraz elementy sterujące do zmiany parametrów i sterowania wynikami modelu.

Wspólne przestrzenie robocze

Użytkownicy mogą korzystać ze wspólnych cyfrowych przestrzeni roboczych do analizy i modyfikowania wyników modeli generatywnych AI. W tych przestrzeniach roboczych mogą być dostępne funkcje takie jak natychmiastowe ulepszanie formularzy, reagowanie na zapytania i kontrola wersji, które sprzyjają płynnej współpracy. Współdzielone przestrzenie robocze w GenAI zapewniają środowiska współpracy, w których wielu użytkowników może wchodzić w interakcje, współpracować i współtworzyć modele generatywne w czasie rzeczywistym. Te współdzielone przestrzenie umożliwiają użytkownikom zdalną współpracę, wymianę pomysłów i wspólną pracę nad projektami, wykorzystując możliwości modeli generatywnych do zwiększenia kreatywności, rozwiązywania problemów i innowacyjności. Ułatwiając współpracę między osobami o zróżnicowanym doświadczeniu i wiedzy specjalistycznej, współdzielone przestrzenie robocze w GenAI promują kulturę pracy zespołowej, dzielenia się wiedzą i zbiorowej inteligencji.

Dynamiczne pętle sprzężenia zwrotnego

Obecnie użytkownicy mogą korzystać z danych przekazywanych do generatywnych modeli AI za pośrednictwem mechanizmów sprzężenia zwrotnego wbudowanych w platformy współpracy. Dane wejściowe modelu, wraz z pożądanymi rezultatami, mogą być iteracyjnie kierowane przez użytkowników poprzez pętlę sprzężenia zwrotnego. Pętla sprzężenia zwrotnego to zestaw operacji przemiennych, dzięki którym wydajność modelu może być poprawiana poprzez iterację, co poprawia doświadczenia użytkownika i udoskonala wyniki poprzez wykorzystanie informacji zwrotnej w czasie rzeczywistym. Te mechanizmy sprzężenia zwrotnego ułatwiają dwustronną komunikację między użytkownikami a modelami generatywnymi, co prowadzi do tego, że użytkownicy dostarczają swoje dane wejściowe, oceniają wyniki, a tym samym dynamicznie modelują zachowanie. Dzięki wprowadzeniu „pętli sprzężenia zwrotnego" do produkcji, systemy GenAI mogą się dostosowywać i ulepszać z czasem, stając się tym samym bardziej trafne i szczegółowe dla użytkowników po każdej interakcji.

Produkty multimodalne

Humanizacja zdania złożonego, która odnosi się do produktów multimodalnych tzw. GenAI, oznacza, że pojedynczy model generatywny jest w stanie dostarczać wiele produktów w różnych modalnościach: język, obrazy, dźwięk i wideo. Ta zdolność sprawia, że modele generatywne są solidne, pozwalając im tworzyć ciągłe i zróżnicowane produkty, które płynnie ze sobą współdziałają, otwierając bogactwo możliwości twórczych, treściowych i interakcji człowiek-maszyna. Dzięki produktom multimodalnym GenAI jest w stanie budować bardziej dynamiczne doświadczenia użytkownika, uwzględniające różne preferencje użytkownika i ułatwiające komunikację w różnych formatach. Produkty w różnych formatach, w tym obrazy, tekst, muzyka i modele 3D, mogą być tworzone przez modele generatywne AI. Treści multimodalne, pozwalające użytkownikom wspólnie odkrywać nowe możliwości twórcze, mogą umożliwiać generowanie treści za pomocą systemów współpracy w czasie rzeczywistym.

Modele konfigurowalne

Platformy współpracy oferują konfigurowalne, generatywne modele sztucznej inteligencji (AI), które użytkownicy mogą precyzyjnie dostroić do swoich indywidualnych wymagań i preferencji. Operatorzy mogą dostosować topologię modelu, dane wykorzystywane do trenowania i inne czynniki, aby dopasować dane wyjściowe modelu do własnych potrzeb. Rysunek 6 przedstawia wartości generatywne przedsiębiorstwa.

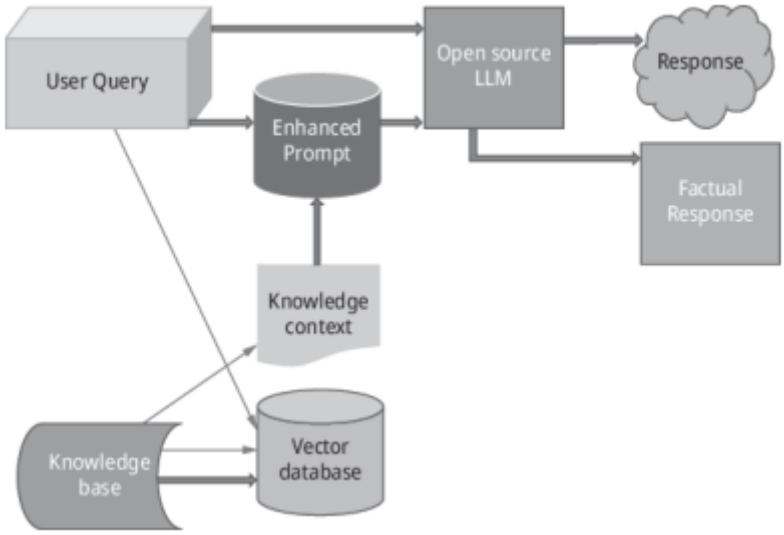

Należy również zauważyć, że konfigurowalne modele w GenAI wspomagają dostrajanie i adaptację do specyfiki danej domeny, dzięki czemu użytkownicy mogą trenować modele na zestawach danych lub zadaniach opartych na danej domenie, aby poprawić wydajność i trafność. Inną kluczową zaletą wstępnie wytrenowanych modeli jest to, że można je precyzyjnie dostroić poprzez ponowne trenowanie na danych specyficznych dla danej domeny, co umożliwia transfer uczenia się, co pomaga w adaptacji modeli do nowych zadań, języków lub domen z niewielką ilością danych oznaczonych. Ten proces dostrajania pomaga zatem użytkownikom nadać modelom specyficzny charakter, zapewniając, że generowane dane wyjściowe odpowiadają ich konkretnym potrzebom i celom.

Prywatność i bezpieczeństwo

Bezpieczeństwo i prywatność prywatnych informacji mają kluczowe znaczenie we współpracy w czasie rzeczywistym z modelami sztucznej inteligencji generującymi treści. Stosowane są silne środki bezpieczeństwa, aby chronić dane użytkownika, zapobiegając w ten sposób niepożądanemu dostępowi.

Skalowalność i wydajność

We współpracy w czasie rzeczywistym z modelami sztucznej inteligencji generującymi treści, bezpieczeństwo i prywatność prywatnych informacji mają kluczowe znaczenie. Narzędzia do współpracy powinny stosować silne środki bezpieczeństwa, aby zabezpieczyć dane użytkownika i zapobiec niepożądanemu dostępowi lub niewłaściwemu wykorzystaniu. Elastyczne i skuteczne systemy współpracy w czasie rzeczywistym są niezbędne do obsługi współpracy na dużą skalę z wykorzystaniem generatywnych modeli sztucznej inteligencji. Może to obejmować wykorzystanie rozproszonych zasobów komputerowych i udoskonalanie algorytmów w celu zwiększenia wydajności.

Integracja efektywnych narzędzi

Systemy współpracy współdziałają z przepływem pracy i narzędziami, które są już w użyciu. Generujące modele sztucznej inteligencji usprawniają proces osadzony w tych połączeniach. Stwarza to możliwość

zwiększenia kreatywności i wydajności, co pomaga w badaniu i promowaniu nowych koncepcji z wykorzystaniem generatywnych modeli sztucznej inteligencji [→29]. Wraz ze stopniowym rozwojem technologicznym projektowane są bardziej przyjazne dla użytkownika systemy, które pomagają ludziom wykazać się kreatywnością poprzez wykorzystanie sztucznej inteligencji.

Wdrażanie technik ochrony prywatności

Rozwiązania zwiększające bezpieczeństwo dzięki wykorzystaniu systemów generatywnych w sztucznej inteligencji (AI) pomagają przede wszystkim w integracji i ochronie danych w fazach szkolenia i rozwoju. Prywatność różnicowa to sprawdzona metoda ochrony prywatności, która gwarantuje, że dane wyjściowe dowolnego modelu generatywnego nie ujawnią informacji związanych z oryginalnymi, indywidualnymi elementami danych. Rysunek 7 przedstawia różne metody i techniki służące ochronie prywatności infrastruktury AI.

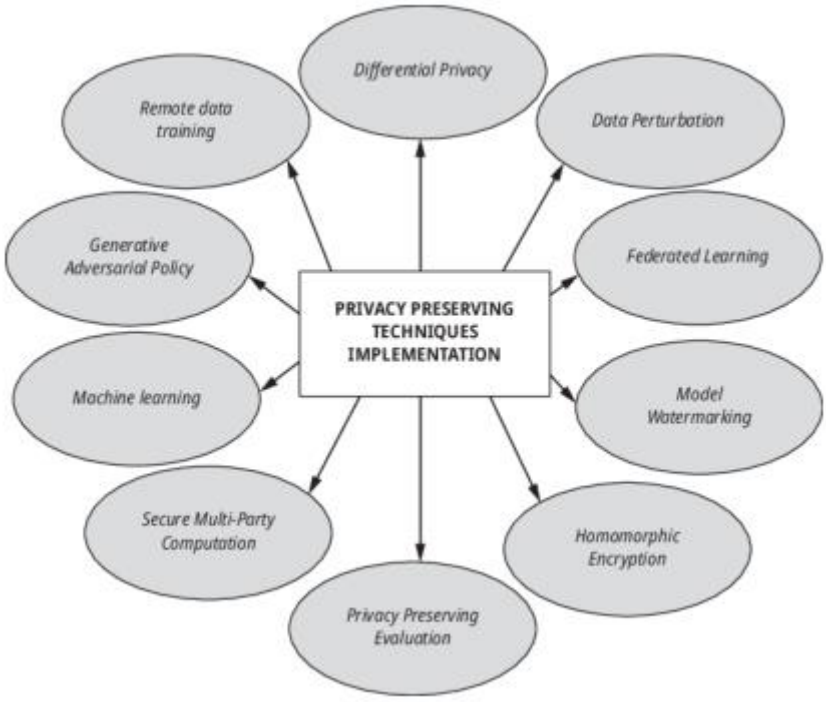

Osiąga się to poprzez celowe dodawanie szumu z wyników modelu, co sprawia, że każdy pojedynczy element danych staje się nieistotny dla reorganizacji hipotezy modelu. Prywatność różnicowa może być dostosowana tak, aby była dostępna w fazach treningu i wnioskowania modeli generatywnych, wspierając prywatność użytkownika i zapewniając jednocześnie dobrą użyteczność. W odniesieniu do federacyjnego uczenia maszynowego, jest to technika oparta na zasadzie peryferycznego udostępniania danych zamiast ich przesyłania. Co więcej, aktualizacje modelu, a nie całe dane treningowe, są wysyłane do centralnego serwera w celu aktualizacji modelu po drugiej stronie sieci. Osiągnięcie tego celu zmniejszyłoby ryzyko ujawnienia poufnych danych użytkownika osobom trzecim, a jednocześnie trenowania modeli generatywnych na rozproszonych zbiorach danych. Federacyjne uczenie jest w pewien sposób dostosowane do aplikacji, w których prywatność danych jest priorytetem, takich jak sektor medyczny i finansowy, gdzie przepisy dotyczące prywatności danych są surowe. Rysunek 8 przedstawia powstającą architekturę dla aplikacji LLM.

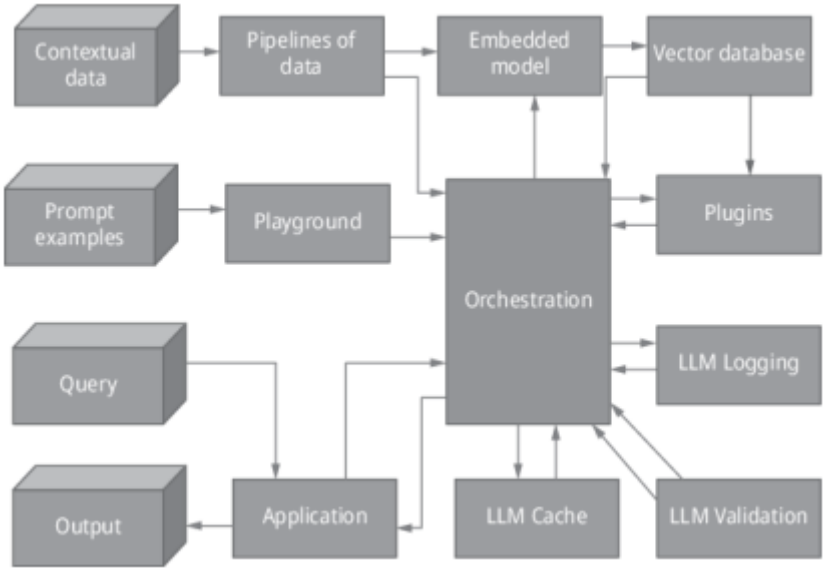

Prywatność różnicowa

Ochrona danych różnicowych to forma ram oceny statystycznej, tworząca tożsamość za pomocą obliczeń. Szyfrowanie różnicowe chroni wrażliwe informacje poprzez dodawanie szumu do danych, które są naśladowane lub oceniane w procesie modelowania. Algorytmy takie jak podwójnie szyfrowany stochastyczny algorytm stopniowego spadku (DP-SGD) mogą być wykorzystywane do trenowania algorytmów uczenia maszynowego, pomimo ochrony tożsamości.

Uczenie federacyjne

Uczenie rozmyte umożliwia trenowanie modeli obejmujących kilka różnych źródeł danych bez udostępniania danych w stanie takim, jakim są. Zamiast konsolidacji danych w jednym miejscu, nauczanie federacyjne polega na harmonijnym trenowaniu sieci w oparciu o informacje regionalne przechowywane na telefonach komórkowych lub komputerach. Ta strategia zapewnia bezpieczeństwo danych poprzez lokalne przechowywanie prywatnych informacji, jednocześnie umożliwiając systemom uzyskiwanie wglądu w informacje internetowe.

Szyfrowanie homomorficzne

Ten rodzaj szyfrowania umożliwia wykonywanie obliczeń na tajnych informacjach, jednocześnie je odblokowując, zachowując prywatność i ułatwiając operacje informacyjne [→30]. W kontekście modeli sztucznej inteligencji generujących treści, homomorficzne hasła cyfrowe mogą być wykorzystywane do przechowywania danych dotyczących edukacji lub zmiennych modelowych, umożliwiając bezpieczne wykonywanie obliczeń przy jednoczesnej ochronie poufnych danych.

Bezpieczne obliczenia wielostronne (SMPC)

SMPC zachęca użytkowników do tworzenia formuł matematycznych, które dostarczają niezbędnych danych wejściowych, zanim zostaną one udostępnione źródłom zewnętrznym. Służą one do dostarczania najbardziej niezawodnych algorytmów, a wzorce danych chronią dane osobowe.

Generative Adversarial Privacy (GAP)

GAP, który działa jako metoda w sieci GAN, zapewnia poufność w zakresie ochrony danych za pomocą modelowania na poziomie maszyn [→31]. Pomaga to w opracowaniu wzorców poufności, które mają na celu obsługę złożonych zestawów danych i nie ujawniają poufnych informacji opartych na wynikach.

Perturbacja danych

Model tworzenia i modyfikacji danych pomaga w modyfikowaniu danych treningowych. Ma to na celu zachowanie użyteczności, a także nauczenie algorytmów, co zapewnia, że dane nie zostaną ujawnione wśród warunków wejściowych.

Znakowanie wodne modeli

Techniki modelowania znakowania wodnego obejmują tożsamości lub wzorce oparte na modelach matematycznych, które umożliwiają wykrywanie nielegalnej dystrybucji. Pomaga to w obsłudze delikatnych modeli danych, a dane są generowane przez sztuczną inteligencję.

Ocena z zachowaniem prywatności

Zachowanie poufności za pomocą modeli oceny pomaga zminimalizować ryzyko związane z danymi. Modele te są testowane na danych wrażliwych, wykorzystując technologie takie jak ocena, chroniąc źródła prywatne.

Udoskonalanie technik wizualizacji naukowej

Ulepszenie wizualizacji naukowej modeli generatywnych przyniosło intrygujące możliwości usprawnienia badania, determinacji i komunikacji wszystkich danych naukowych. Ulepszone modele wizualizacji naukowej działają z wykorzystaniem następujących kluczowych komponentów:

* Wyzwanie polega na wizualizacji i analizie zbiorów danych o dużej liczbie wymiarów. Modele generatywne uczą się, reprezentując te wielowymiarowe zbiory danych z niewielką liczbą wymiarów lub ich ograniczoną liczbą, co ułatwia ich analizę [→33]. Zatem, łącząc techniki takie jak UMAP, modele generatywne pomagają w ulepszonych wizualizacjach lokalnej i globalnej struktury danych.

* Interaktywne narzędzia wizualizacyjne pomagają naukowcom w eksploracji złożonych zbiorów danych w czasie rzeczywistym, gdzie próbują tworzyć zmienne wzorce na danych wejściowych, odpowiednio eksplorując dane i stosując precyzyjne sformułowania.

* Uzupełnienia modeli generatywnych, nawet w przypadku brakujących zbiorów danych, tworzą syntetyczne zbiory punktów danych w celu wypełnienia luk [→34]. Może to zwiększyć precyzję przepustowości poprzez głębsze zrozumienie skomplikowanej struktury wzorców, tworząc różnorodne zestawy rozszerzonych zbiorów danych.

* Modele generatywne identyfikują wzorce i struktury, których surowe dane mogą nie ujawniać. Reprezentacje te można wykorzystać do tworzenia atrakcyjnych wizualizacji z różnymi zestawami powiązanych danych.

* Modele generatywne, w tym VAE i GAN, tworzą realistyczne próbki danych o rozkładach liniowych.

Udoskonalanie technik wizualizacji naukowej

Ulepszenie wizualizacji naukowej modeli generatywnych przyniosło intrygujące możliwości usprawnienia badania, determinacji i komunikacji wszystkich danych naukowych. Ulepszone modele wizualizacji naukowej działają z wykorzystaniem następujących kluczowych komponentów:

* Wyzwanie polega na wizualizacji i analizie zbiorów danych o dużej liczbie wymiarów. Modele generatywne uczą się, reprezentując te wielowymiarowe zbiory danych z niewielką liczbą wymiarów lub ich ograniczoną liczbą, co ułatwia ich analizę [→33]. Zatem, łącząc techniki takie jak UMAP, modele generatywne pomagają w ulepszonych wizualizacjach lokalnej i globalnej struktury danych.

* Interaktywne narzędzia wizualizacyjne pomagają naukowcom w eksploracji złożonych zbiorów danych w czasie rzeczywistym, gdzie próbują tworzyć zmienne wzorce na danych wejściowych, odpowiednio eksplorując dane i stosując precyzyjne sformułowania.

* Uzupełnienia modeli generatywnych, nawet w przypadku brakujących zbiorów danych, tworzą syntetyczne zbiory punktów danych w celu wypełnienia luk [→34]. Może to zwiększyć precyzję przepustowości dzięki głębszemu zrozumieniu skomplikowanej struktury wzorców, tworząc różnorodne zestawy rozszerzonych zbiorów danych.

* Modele generatywne identyfikują wzorce i struktury, których surowe dane mogą nie ujawniać. Reprezentacje te można wykorzystać do tworzenia atrakcyjnych wizualizacji z różnymi zestawami powiązanych danych.

* Modele generatywne, w tym VAE i GAN, tworzą realistyczne próbki danych o rozkładach liniowych.

* Tworzy to również sztuczne zbiory danych do prezentacji i badania możliwych sytuacji.

* Modele generatywne usprawniają rekonstrukcję i usuwanie szumów, na przykład w obrazowaniu medycznym i mikroskopii. Modele generatywne rekonstruują obrazy wysokiej jakości, co przekłada się na lepszą wizualizację obrazów naukowych [→35].

* Dodając te taktyki bezpieczeństwa do modeli GenAI, naukowcy i programiści mogą tworzyć usługi, które chronią poufność i bezpieczeństwo użytkowników, jednocześnie oferując zaawansowane i kreatywne funkcjonalności.

* Przed zastosowaniem akceptowalnych procedur konieczne jest prawidłowe oszacowanie specyficznych wymagań i ograniczeń dotyczących prywatności w każdej lokalizacji.

Wykorzystanie technologii blockchain dla zaufania i przejrzystości

Wykorzystanie walut cyfrowych do budowania zaufania do modeli AI jest możliwe dzięki generowaniu różnorodnych rozwiązań dla kluczowych kwestii, takich jak legalność platformy i źródła danych.

Koncepcje blockchain są wykorzystywane w następujących kryteriach:

Weryfikacja modelu i wiarygodność

* Wykorzystanie technologii blockchain umożliwia stworzenie trwałego repozytorium metod AI, w tym frameworka, charakterystyk i danych instruktażowych.

* Użytkownicy mogą weryfikować wiarygodność i poprawność scenariuszy, zapewniając, że rzadko były one celowo modyfikowane lub aktualizowane, poprzez przechowywanie informacji o modelu w rozproszonym rejestrze.

Pochodzenie i własność danych

* Jako rozproszony rejestr, blockchain może być wykorzystywany do śledzenia źródła i praw autorskich do danych potrzebnych do trenowania algorytmów sztucznej inteligencji generujących informacje [→36].

* Blockchain umożliwia klientom monitorowanie pochodzenia fragmentów danych, sprawdzanie ich poprawności oraz zapewnienie zgodności z obowiązkami dotyczącymi danych.

Przejrzyste procesy uczenia się

* Technologia blockchain może ułatwić zwiększenie otwartości podczas trenowania algorytmów uczenia maszynowego sztucznej inteligencji poprzez rejestrowanie każdego etapu procesu w zdecentralizowanym systemie pamięci masowej.

* Obejmuje to śledzenie zebranych danych, trenowanie parametrów modelu i dostosowywanie hiperparametrów, a także metryki oceny.

* Dzięki opracowaniu przejrzystego śladu audytu użytkownicy mają możliwość zrozumienia procesu generowania koncepcji, a jednocześnie przestrzegania najsurowszych norm i zasad etycznych [→37].

Zdecentralizowane zarządzanie modelami

* Zdecentralizowane decyzje dotyczące generatywnych modeli AI mogą być ułatwione dzięki rozwiązaniom zarządzania opartym na technologii blockchain. Obejmuje to protokoły komentowania aktualizacji modeli, dostosowywania parametrów i wyboru źródeł danych treningowych.

* Zdecentralizowany model zarządzania umożliwia zapewnienie sprawiedliwości, inkluzywności i przejrzystości w obsłudze metod modelowych.

Przejrzyste wyniki sieci

* Technologia blockchain umożliwia dostarczanie przejrzystych dokumentów dotyczących wyników modeli GenAI.

* Obejmuje to przechowywanie rekordów konfiguracji i

danych wejściowych wymaganych do uzyskania każdego wyniku, a także godzin, minut i podpisów, które są kryptograficznie niezbędne do potwierdzenia ważności utworzonych informacji [→38].

Wnioski i przyszłe kierunki rozwoju

Podsumowując, modele generatywne AI są uważane za awangardę nowatorskich innowacji, które zapewniają nowe możliwości koncentrujące się na tworzeniu, ulepszaniu i rozumieniu wzorców danych na szerszym obszarze. Modele te przyniosły lepsze rezultaty w dostarczaniu i uzyskiwaniu realistycznych obrazów, tekstu i wszystkich innych źródeł, które pomagają w usprawnieniu badań i tworzeniu wyrażeń. Algorytmy generatywne AI są przygotowane do skoncentrowania się na innowacjach i znaczącym wzroście. Przyszłe kierunki rozwoju koncentrują się głównie na ulepszaniu projektów zastosowań transdyscyplinarnych wraz z rozwojem AI. W miarę rozwoju i upowszechniania się modeli generatywnych, z pewnością odegrają one ważną rolę w dającej się przewidzieć przyszłości, dzięki zdefiniowanym narzędziom kreatywnym, a także postępowi medycznemu i technologicznemu. Rozwiązując te kwestie etyczne i przesuwając granice badań, w pełni wykorzystamy potencjał modeli AI, co wygeneruje pozytywne zmiany, tworząc rewolucję w platformie społecznej.